

Capítulo 6

La percepción de
calidad de servicio
como determinante
de la recomendación:
una predicción
mediante inteligencia
artificial para los
hoteles en Cartagena

Capítulo 6

La percepción de calidad de servicio como determinante de la recomendación: una predicción mediante inteligencia artificial para los hoteles en Cartagena

{ María Andreína Moros Ochoa, Jenny-Paola Lis-Gutiérrez, Gilmer Yovanni Castro Nieto, César Augusto Vargas y Juan Carlos Rincón

Resumen

Este capítulo identifica las variables que permiten explicar la recomendación o no de los hoteles, de usuarios en la ciudad de Cartagena, a partir de algoritmos de inteligencia artificial. Se identificaron los algoritmos que mejor desempeño tenían: Random Forest (100%), SVM (100%), KNN (98%), AdaBoost (94%), árbol de decisión (92%), redes neuronales (86%) y CN2 (82%). Para las alternativas de tal vez recomendaría y no recomendaría, no hubo algoritmos con capacidad de predicción superior al 75%.

Palabras clave: calidad de servicio, Caltur, inteligencia artificial, algoritmos de predicción, turismo, hotelería, Cartagena.

Introducción

El turismo ha cobrado importancia en la economía de los países. En el 2017 representó el 10% del PIB mundial y uno de cada 10 puestos de trabajo (UNWTO, 2018). Situación avalada por el Consejo Mundial de Viajes y Turismo, que afirma que su contribución total al PIB mundial fue de USD 8.272 billones (10,4%) y generó empleo a 313.221.000 personas (9,9%) en el 2017. Además, las llegadas internacionales a América aumentaron en 7 millones en el 2016, hasta alcanzar casi los 200 millones y la demanda de viajes permaneció fuerte en la región. Por subregiones, América del Sur lideró con 7% más, aportando Colombia 11% (Consejo Mundial de Viajes y Turismo - WTTC, 2018).

Por otro lado, es importante mencionar algunas características del turismo en Colombia y específicamente de la ciudad de Cartagena como atractivo turístico mundial, que la han hecho merecedora de reconocimientos como un excelente destino turístico; entre los más destacados están: Forbes, New York Times Travels, Huffington Post, BBC Travel y Trip Advisor. Colombia hoy cuenta con más de 14.000 establecimientos de alojamiento y hospedaje activos y en el departamento de Bolívar cerca de 700. Cartagena tiene en el momento 331 establecimientos que equivalen a 11.434 habitaciones y el 54% de estos son hoteles clasificados en cuatro y cinco estrellas (Bello, 2015).



En la ciudad de Cartagena el turismo es el principal generador de empleo con 14.574 empleados y 2.836 empresas constituidas formalmente; además, su ocupación hotelera es una de las más altas en Colombia con 66,20% en el 2017.

Según la Cámara de Comercio de Cartagena (2017), en la ciudad el turismo es el principal generador de empleo con 14.574 empleados y 2.836 empresas constituidas formalmente; además, su ocupación hotelera es una de las más altas en Colombia con 66,20% en el 2017. En este contexto, la pregunta orientadora corresponde a ¿cómo se puede predecir la recomendación o no de un hotel en Cartagena? Para ello se emplean diferentes algoritmos de inteligencia artificial.

1. Contexto

Los 24 hospedajes registrados en el 2015 con más de 100 habitaciones corresponden a casi el 50% de la oferta de habitaciones en Cartagena. Se espera que este sector siga

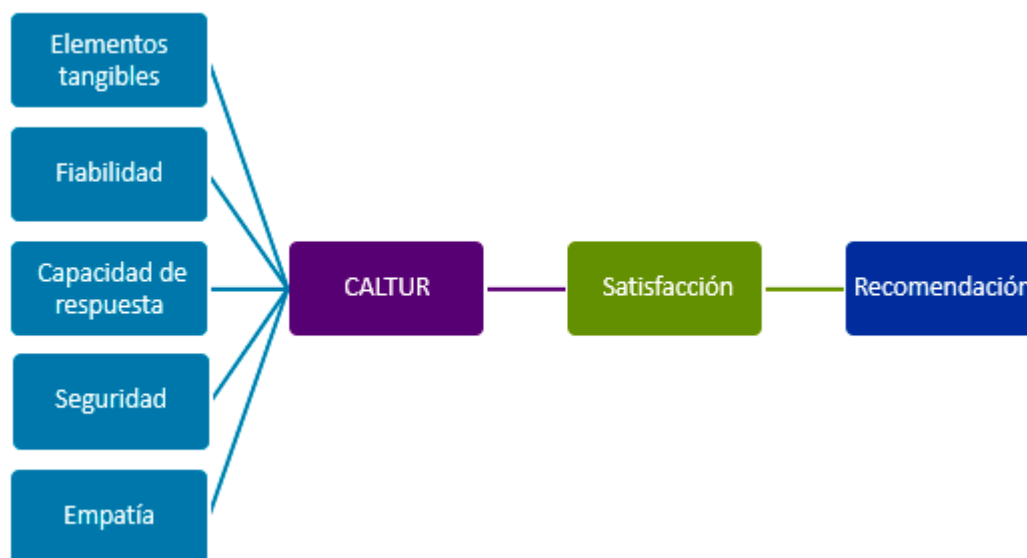
creciendo con los 18 proyectos que se tienen previstos para el 2018 en Cartagena; esto significaría 1.764 habitaciones adicionales. El gran potencial de Cartagena como destino turístico se puede ratificar con la tasa del 13 % de crecimiento promedio de turismo extranjero (González, 2017).

Estos datos resaltan la importancia de continuar desarrollando investigación en turismo. Así, en el 2017 se realizó una medición de calidad de servicio utilizando el modelo Caltur, el cual se aplicó a una muestra en la ciudad de Cartagena (Colombia). El modelo Caltur tiene base en el conocido modelo Servqual que se refiere a una escala de múltiples elementos para medir las prestaciones al cliente sobre la calidad del servicio. Parasuraman, Berry y Zeithaml (1988) plantearon la medición de la calidad de servicio percibido como el grado de discrepancia entre las percepciones y las expectativas de los consumidores. Ellos comenzaron sus estudios en 1983, apoyándose en estudios previos como el de Sasser, Olsen y Wyckoff (1978). Después, Parasuraman, Berry y Zeithaml (1994) finalmente definieron el modelo en cinco dimensiones y 22 variables.

Después de analizar los resultados obtenidos de la aplicación del Servqual como base en el sector turístico entre los que destacan: Vergara, Quesada y Blanco (2011), Berné, García, García y Mugica (2013), Vega, Casielles y Martín (2015), Monsalve y Hernández (2015), Moreno y Moreno (2016), Moros, Rincón, Castro, Vilorio y Ariza (2016) realizaron una adaptación del Servqual (tomando en cuenta variables tecnológicas), el cual mantuvo 22 variables distribuidas en las cinco dimensiones originales: i) elementos tangibles; ii) fiabilidad; iii) capacidad de respuesta; iv) seguridad; v) empatía. Posteriormente, se realizó un nuevo ajuste y una validación adicional al modelo, esta nueva versión se denominó Caltur. Este modelo se aplicó en seis ciudades iberoamericanas (Lis-Gutiérrez et al., 2019), una de ellas fue Cartagena. Es importante destacar que el Caltur mantiene las cinco dimensiones originales: elementos tangibles, fiabilidad, capacidad de respuesta, seguridad, empatía, tal y como se muestra en la Figura 1.

Así, estas cinco dimensiones comprenden 16 ítems a los que quedó definitivamente reducido el modelo (como ya se mencionó), los cuales miden, por una parte, los niveles esperados del servicio en general (la expectativa que tenía creada) y, por otra, los mismos ítems pero referidos al nivel percibido del servicio entregado por una empresa de servicio en particular (la percepción real del cliente sobre la característica enunciada). Estos ítems se evalúan mediante una escala de Likert de siete puntos que van desde el 1 (totalmente en desacuerdo) hasta el 7 (totalmente de acuerdo).

Figura 1. Dimensiones del modelo Caltur



Fuente: elaboración propia.

Se reitera que las dimensiones del Caltur son las originales del Servqual, las cuales son utilizadas en recientes mediciones de percepción de calidad de servicio en el sector hotelero. Por ejemplo, Ahmad, Ahmad y Papastathopoulos (2018) aplicaron las cinco dimensiones para medir la percepción de calidad y su impacto en la satisfacción de los clientes. Lee y Cheng (2018) utilizaron cuatro y agregaron la comunicación verde y la reducción de energía en su modelo GLSERV. Lestari y Saputra (2018) y Lestari y Laode (2018) emplearon las cinco dimensiones para medir cuál era la más importante en los hoteles de 2/3 y 4/5 estrellas, respectivamente. Keshavarz y Jamshidi (2018) utilizaron la “tangibilidad”, la capacidad de respuesta, la fiabilidad, la empatía, la seguridad y agregaron la conveniencia y la sociabilidad como nuevas dimensiones, para medir la calidad en la búsqueda de satisfacción de las necesidades de los turistas internacionales, aumentando así la lealtad del turista a través del valor percibido y su satisfacción.

En el siguiente apartado se explica la metodología utilizada para el análisis que se realiza en este trabajo.

2. Metodología

En esta sección se presentan los datos, variables y método empleado para el análisis.

2.1 Datos

En el 2017, el Caltur se aplicó en seis ciudades, una de ellas Cartagena. En este caso, se aplicó en una muestra de 68 clientes hoteleros de la ciudad de Cartagena (Tabla 1). Para validar el tamaño de la muestra se utilizó el *software* G*Power versión 3.1.9.2, para lo cual se tomó una probabilidad de cometer el error tipo I (alfa) de 0,05 y una probabilidad de cometer el error tipo II (beta) de 0,2 y un tamaño del efecto alto de 0,8 según valores de referencia citados por Castro y Martini (2014). De esta forma, el cálculo dio como resultado un tamaño de 21 individuos por grupo (hombres y mujeres), lo cual justifica el tamaño de los encuestados.

Tabla 1. Composición de la muestra de Cartagena

		Frecuencia	Porcentaje
Válido	Masculino	42	61,8
	Femenino	26	38,2
	Total	68	100,0

Fuente: salida SPSS.

2.2 Algoritmos utilizados

En la literatura reciente hay varias aplicaciones de aprendizaje automático; entre los trabajos más recientes se encuentran los siguientes: Alic *et al.* (2019) emplean diferentes algoritmos aplicados a datos provenientes de EUBra-BIGSEA (Europe–Brazil Collaboration of Big Data Scientific Research Through Cloud-Centric Applications), para el análisis de los datos de transporte público. Los autores usaron modelos descriptivos y predictivos. Por su parte, Banik, Ekbal y Bhattacharyya (2019) aplican el aprendizaje basado en la decodificación. Kannan y Vasanthi (2019) utilizan algoritmos de aprendizaje automático con curva ROC para predecir y diagnosticar la enfermedad cardíaca en India, comparan la precisión de cuatro algoritmos de aprendizaje automático mediante los 14 atributos de los conjuntos de datos cardíacos UCI. Un trabajo similar, pero aplicado a la enfermedad del hígado graso, considerando 577 pacientes (Wu, 2019).

Para el caso específico de turismo, se identificaron las obras de Sun, Wei, Tsui y Wang (2019), la cual realiza la predicción de llegadas de turistas empleando aprendizaje automático y algunos índices de búsquedas en Internet. Giglio, Bertacchini, Bilotta y Pantano (2019) realizan algo similar para seis ciudades de Italia usando las redes sociales. Específicamente, para el caso de aplicaciones en los hoteles se

encuentran los trabajos de Ku, Chang, Wang, Chen y Hsiao (2019), Nilashi *et al.*, (2019), Shin, Du y Xiang (2019) y Hassan y Abdulwahhab (2019) que buscan predecir la recomendación de los visitantes a los diferentes hoteles.

Para el procesamiento de la información se aplicaron distintos métodos (algoritmos) de aprendizaje supervisado, los cuales se sintetizan en la Tabla 2.

Tabla 2. Algoritmos de aprendizaje supervisado

Método	Síntesis
AdaBoost	Es un algoritmo de aprendizaje adaptativo que combina clasificadores débiles y se adapta a la dureza de cada muestra de entrenamiento, logrando clasificadores robustos. Permite la clasificación binaria y multiclase.
Random Forest	Emplea un conjunto de árboles de decisión para la clasificación y proyección. Es un procedimiento no paramétrico, que puede usarse cuando: i) hay variables correlacionadas; ii) pocos datos; iii) interacciones complejas; iv) datos faltantes.
SVM (Support Vector Machines)	Permite la clasificación binaria y multiclase. Hace uso del análisis de regresión y clasificación.
Red neuronales	Hace uso del algoritmo de perceptrón multicapa (MLP) con retropropagación. La ventaja es que puede aprender modelos no lineales.
KNN	Este mecanismo de reconocimiento de patrones no paramétricos, se basa en las instancias de entrenamiento más cercanas, siendo un algoritmo de k vecinos más cercanos. También se conoce como aprendizaje perezoso.
Naive Bayes	Un clasificador probabilístico rápido y simple basado en el teorema de Bayes con la suposición de independencia de características. Se asume que la ausencia o presencia de una característica no está relacionada con la presencia o ausencia de otra característica. Su ventaja es que requiere de pocos datos para el entrenamiento.
Algoritmo de aprendizaje del árbol de decisión	Se emplea para datos discretos y continuos. Se basa en la predicción del valor de una variable de destino en función de diversas variables de entrada.


Fuente: Lis-Gutiérrez, Aguilera-Hernández y Escobedo-David (2018).

3. Resultados

Estos clientes hicieron la evaluación de cada una de las variables que componen el Caltur y según la escala utilizada, se obtuvieron los resultados que se muestran en el Gráfico 1. Al observar estos porcentajes se aplicó la prueba Chi-cuadrado entre la

variable Cultur (percepción de calidad) y sexo y se obtuvo un valor $p < ,05$, con lo cual se prueba que existen diferencias significativas entre la percepción de calidad de servicio entre hombres y mujeres entre los clientes hoteleros de Cartagena (Tabla 3). Sería interesante en futuras investigaciones indagar sobre los factores influyentes en que hombres y mujeres que componen la muestra estudiada en Cartagena tengan una diferencia significativa en la percepción de la calidad de servicio hotelero.

Gráfico 1. Percepción de calidad de servicio de los clientes hoteleros en Cartagena



Fuente: elaboración propia.

Tabla 3. Percepción de calidad de servicio de los clientes hoteleros en Cartagena

		P26SEXO		Total
		Masculino	Femenino	
CALTUR	Deficiente	54,8%	61,5%	57,4%
	Aceptable	2,4%	23,1%	10,3%
	Buena	42,9%	15,4%	32,4%
Total		100,0%	100,0%	100,0%

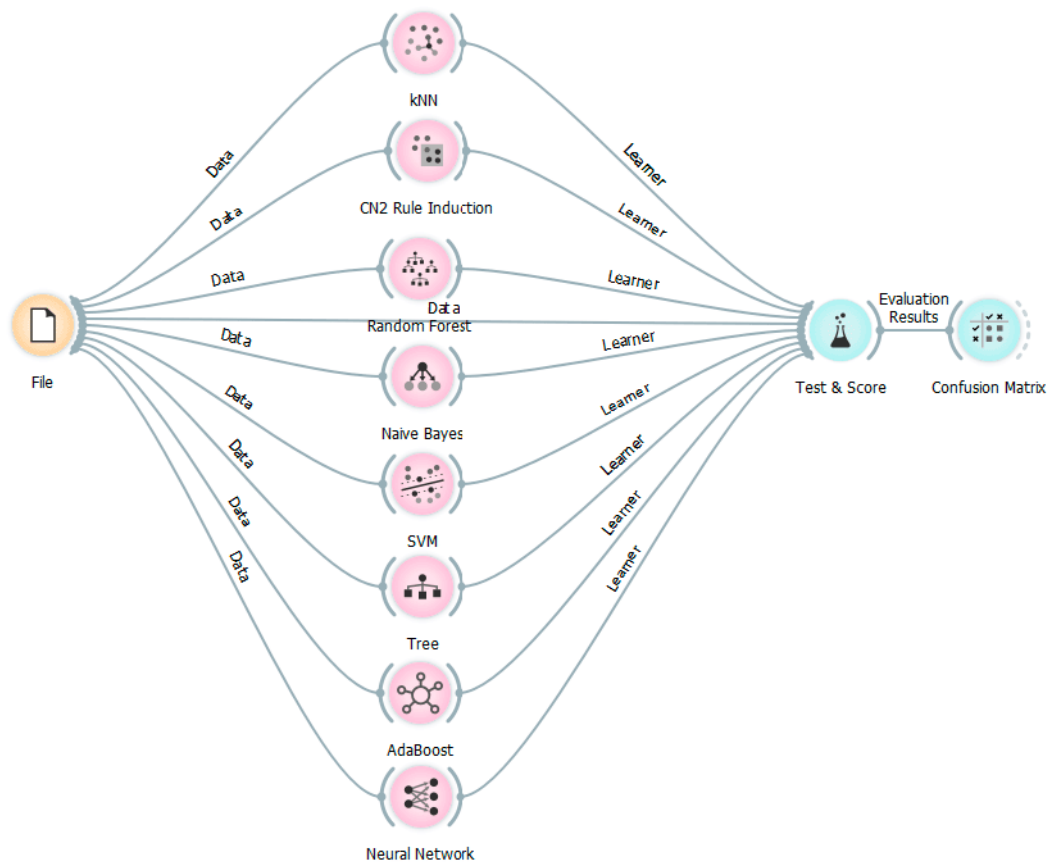
Fuente: salida SPSS.

Una vez analizados estos resultados obtenidos en el 2017, en esta investigación se propone utilizar la inteligencia artificial para predecir la recomendación que estos clientes harían del hotel.

En el Gráfico 2 se muestran los diferentes algoritmos de aprendizaje y predicción empleados y en el Gráfico 3 los cálculos de precisión de los mismos. Cabe aclarar que se usó la opción de validación cruzada aleatoria. Este método consistió en

dividir aleatoriamente el conjunto de datos de entrenamiento y prueba, mediante 10 iteraciones. El ajuste se obtiene de la media aritmética de los valores obtenidos para cada una de las iteraciones. En el Gráfico 4 se aprecia la matriz de confusión para cada algoritmo. Se empleó el *software* Orange, el cual ha sido usado en trabajos recientes como los de Kühnle *et al.* (2018), Da Silva, Elnabarawy y Wunsch (2019), Alic *et al.* (2019), Banik *et al.* (2019), Dzemyda, Kurasova, Medvedev y Dzemydaitė (2019) y Sunil y Vinay (2019).

Gráfico 2. Imagen de la representación del modelo usando Orange



Fuente: elaboración propia usando Orange (Demsar *et al.*, 2013).

Se empleó como evaluación el *Leave-one-out*, el cual se trata de una validación cruzada, dejando en cada caso uno de los sujetos por fuera; es decir, para cada iteración se tiene una sola muestra para prueba y el resto de datos son los de entrenamiento. Se consideran cinco casos, la respuesta promedio, recomienda, tal vez recomienda, no recomienda.

Gráfico 3. Cálculo de los algoritmos de aprendizaje y predicción para la muestra completa

Test & Score						Test & Score					
Settings						Settings					
Sampling type: Leave one out Target class: Average over classes						Sampling type: Leave one out Target class: 1					
Scores						Scores					
Method	AUC	CA	F1	Precision	Recall	Method	AUC	CA	F1	Precision	Recall
AdaBoost	0.705	0.779	0.768	0.760	0.779	Naive Bayes	0.662	0.723	0.909	0.600	
Naive Bayes	0.744	0.544	0.606	0.740	0.544	AdaBoost	0.868	0.913	0.887	0.940	
Tree	0.704	0.735	0.725	0.721	0.735	Tree	0.838	0.893	0.868	0.920	
Random Forest	0.766	0.779	0.716	0.707	0.779	CN2 rule inducer	0.721	0.812	0.804	0.820	
kNN	0.686	0.765	0.703	0.695	0.765	Neural Network	0.735	0.827	0.796	0.860	
Neural Network	0.733	0.676	0.658	0.643	0.676	Random Forest	0.809	0.885	0.794	1.000	
CN2 rule inducer	0.570	0.632	0.626	0.620	0.632	kNN	0.779	0.867	0.778	0.980	
SVM	0.727	0.735	0.623	0.541	0.735	SVM	0.735	0.847	0.735	1.000	

Sí recomienda

Test & Score						Test & Score					
Settings						Settings					
Sampling type: Leave one out Target class: 2						Sampling type: Leave one out Target class: 3					
Scores						Scores					
Method	AUC	CA	F1	Precision	Recall	Method	AUC	CA	F1	Precision	Recall
kNN	0.809	0.316	0.600	0.214	0.214	Neural Network	0.926	0.286	0.333	0.250	
Random Forest	0.809	0.316	0.600	0.214	0.214	AdaBoost	0.912	0.250	0.250	0.250	
AdaBoost	0.779	0.400	0.455	0.357	0.357	CN2 rule inducer	0.897	0.222	0.200	0.250	
Tree	0.765	0.333	0.400	0.286	0.286	Naive Bayes	0.706	0.231	0.136	0.750	
Naive Bayes	0.721	0.296	0.308	0.286	0.286	kNN	0.941	0.000	0.000	0.000	
Neural Network	0.691	0.160	0.182	0.143	0.143	Random Forest	0.941	0.000	0.000	0.000	
CN2 rule inducer	0.647	0.077	0.083	0.071	0.071	SVM	0.941	0.000	0.000	0.000	
SVM	0.794	0.000	0.000	0.000	0.000	Tree	0.868	0.000	0.000	0.000	

No recomienda

Fuente: elaboración propia usando Orange (Demsar *et al.*, 2013).

Después de aplicar ocho algoritmos de aprendizaje supervisado a la información de las encuestas, fue posible identificar que:

- Al considerar los resultados promedio, los siguientes algoritmos tienen una capacidad predictiva entre 70% y 76%: AdaBoost, Naive Bayes, árbol de decisión y Random Forest (Gráfico 3). El algoritmo con menor capacidad de predicción fue el SVM.
- Al considerar la predicción de si recomienda el hotel, los siguientes algoritmos tienen una capacidad predictiva entre 80% y 90,9%: Naive Bayes, AdaBoost, árbol de decisión y CN2. Entre 73% y 79% se ubican las redes neuronales, Random Forest, KNN y SVM (Gráfico 3). En este caso

todos los algoritmos tienen una capacidad de predicción alta y muy alta.

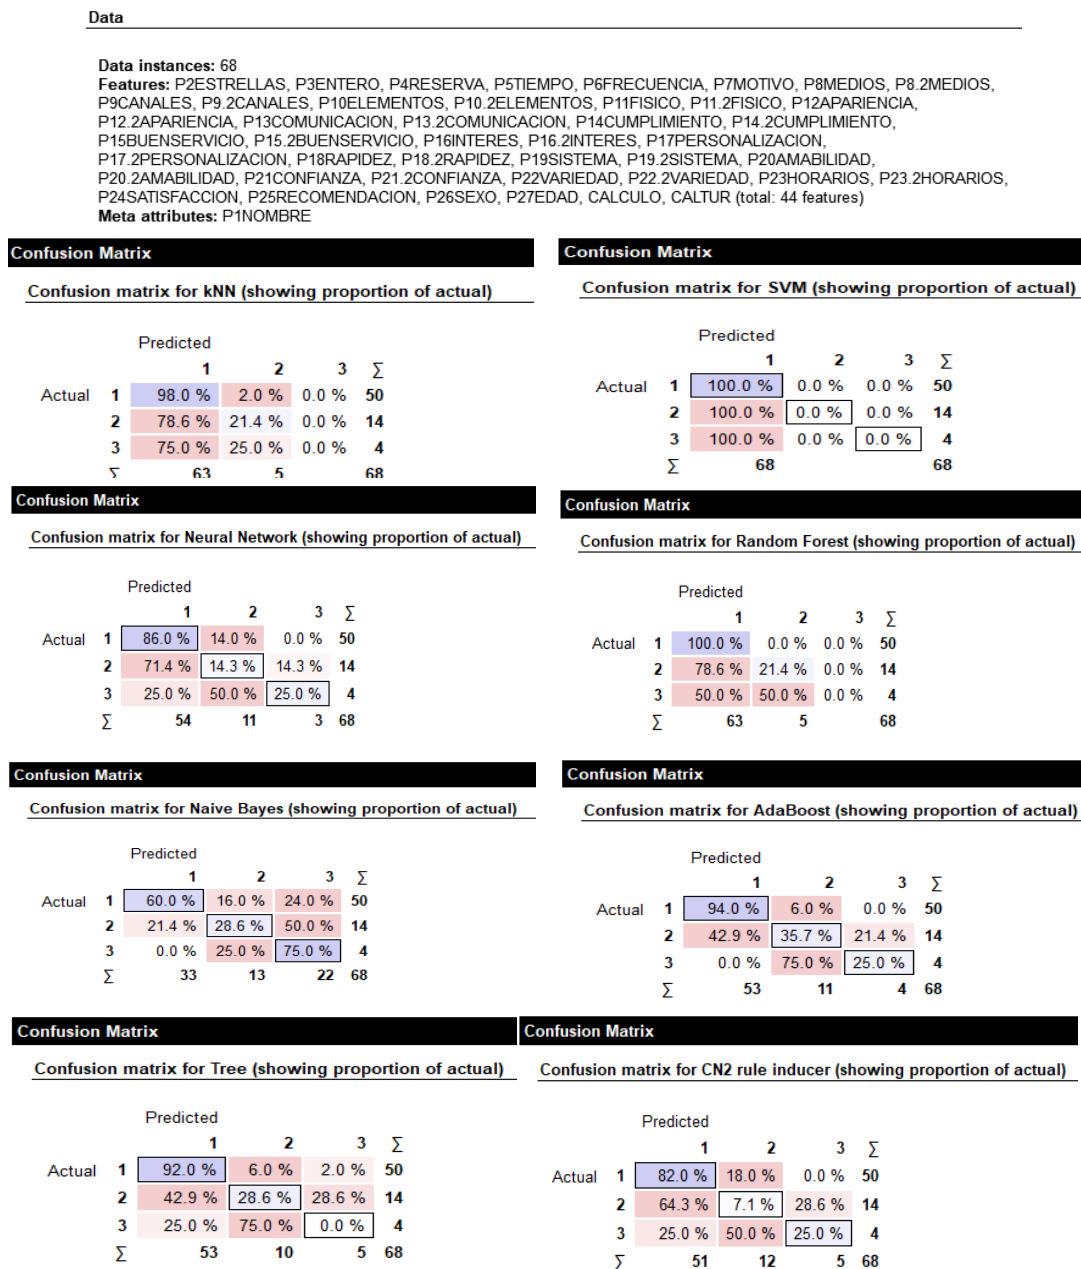
- Para el caso de *tal vez recomendaría*, solo dos algoritmos superaron el 60 %, KNN y Random Forest, lo que implica que el modelo no es adecuado para este tipo de predicción.
- Para el caso de *no recomendaría*, ningún algoritmo fue superior al 50 %, lo que implica que el modelo no es adecuado para este tipo de predicción.
- Considerando el Gráfico 4, es decir, la matriz de confusión, es posible indicar que:
 - Los mejores algoritmos para la predicción correcta de la *recomendación* serían:
 - Random Forest: 100 %
 - SVM: 100 %
 - KNN: 98 %
 - AdaBoost: 94 %
 - El árbol de decisión: 92 %
 - Redes neuronales: 86 %
 - CN2: 82 %
 - Ningún algoritmo clasifica correctamente en más del 30 % a quienes *tal vez recomendarían*.
 - El mejor algoritmo para la predicción correcta de la *no recomendación* sería el Naive Bayes con 75 % de clasificaciones correctas.
 - A pesar de que el SVM predice el 100 % de las recomendaciones, el problema radica en que no hace la distinción para el resto de alternativas, es decir, que no importa los datos, siempre clasificará en la categoría de recomendación.

Ahora bien, con respecto al Gráfico 5, se encuentra el árbol de decisión para la recomendación, se halla que las variables más relevantes para la recomendación de un hotel corresponden a:

- Grado de satisfacción antes que tener medios tecnológicos actualizados.
- La satisfacción real por los empleados que atiendan sus necesidades de forma personalizada y horarios convenientes para todos, después de haber sido usado el servicio, antes que los canales de distribución tecnológicos.

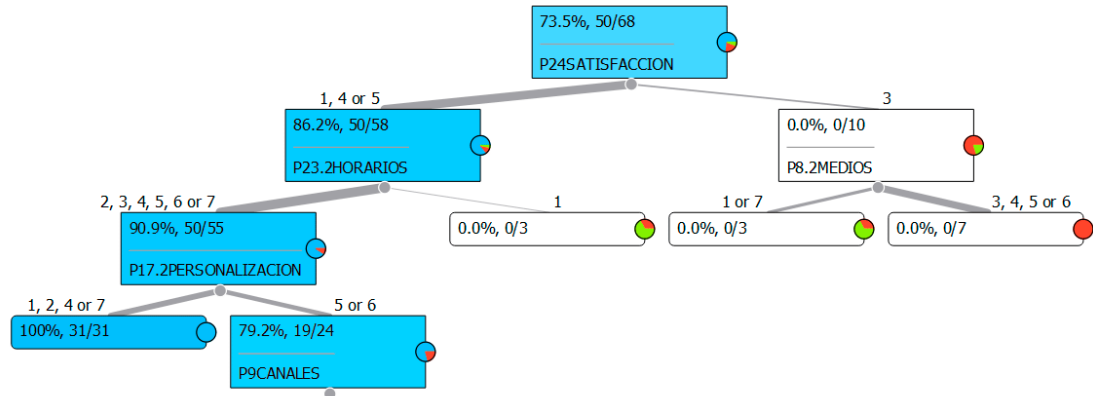
La percepción de calidad de servicio como determinante de la recomendación

Gráfico 4. Matriz de confusión para cada algoritmo (muestra completa)



Fuente: elaboración propia usando Orange (Demsar *et al.*, 2013).

Gráfico 5. Árbol de decisión para personas que sí recomendarían el hotel



Fuente: elaboración propia usando Orange (Demsar *et al.*, 2013).

Conclusiones

En este capítulo se buscó identificar las variables que permitían explicar la recomendación o no de los hoteles, por parte de usuarios en la ciudad de Cartagena, a partir de algoritmos de inteligencia artificial. Se logró identificar que los algoritmos que mejor desempeño tenían fueron: Random Forest (100 %), SVM (100 %), KNN (98 %), AdaBoost (94 %), árbol de decisión (92 %), redes neuronales (86 %) y CN2 (82 %). Para las alternativas de *tal vez recomendaría* y *no recomendaría*, no hubo algoritmos con capacidad de predicción superior al 75 %. Comprobando que el *machine learning* es una valiosa oportunidad para medir la satisfacción y la probabilidad de recomendación de un cliente.

La originalidad de este trabajo se encuentra enmarcada en dos elementos: i) trabajo directo con una parte de los usuarios de servicios hoteleros; ii) el uso de una técnica de análisis no empleada hasta ahora para comprender la relación entre percepción de calidad de servicio, la satisfacción y la recomendación. Este método permitió determinar que las variables más relevantes para la posibilidad de recomendación de un cliente hotelero en Cartagena son: la satisfacción real después de haber usado el servicio por los empleados que atiendan sus necesidades de forma personalizada y los horarios convenientes para todos, antes que por los canales de distribución tecnológicos. Es decir, para ellos son más importantes las variables que se encuentran en las dimensiones de capacidad de respuesta y empatía, que aquellas que se enmarcan en los elementos tangibles, por lo que las estrategias de calidad de servicio deben enfocarse en aquellas variables que reflejen atención individualizada para el cliente.

En las recomendaciones para futuros estudios se encuentran: i) ampliar la muestra, para tener más potencia predictiva; ii) replicar este estudio en otras ciudades y verificar si los algoritmos identificados predicen de manera eficiente los niveles de ingreso de la población que retornó.

Dentro de las sugerencias derivadas para futuros trabajos se encuentra un ajuste al modelo utilizado, ya que la medición de la percepción de la calidad del servicio debe revisarse y adaptarse teniendo en cuenta otras variables de innovación. Igualmente, dentro de las posibles aplicaciones se encuentra la posibilidad de repetición de un cliente al tomar el servicio del hotel y al análisis de sentimientos a partir de la información disponible en redes sociales o páginas de recomendación de libre acceso.

Referencias

- Ahmad, S. Z., Ahmad, N., & Papastathopoulos, A. (2018). Measuring service quality and customer satisfaction of the small-and medium-sized hotels (SMSHs) industry: Lessons from United Arab Emirates (UAE). *Tourism Review*. <https://doi.org/10.1108/TR-10-2017-0160>.
- Alic, A. S., Almeida, J., Aloisio, G., Andrade, N., Antunes, N., Ardagna, D., ..., & Brito, A. (2019). BIGSEA: A Big Data analytics platform for public transportation information. *Future Generation Computer Systems*. Disponible en <https://www.sciencedirect.com/science/article/pii/S0167739X18304448>.
- Banik, D., Ekbal, A., & Bhattacharyya, P. (2019). Machine learning based optimized pruning approach for decoding in statistical machine translation. *IEEE Access*, 7, 1736-1751. Disponible en <https://ieeexplore.ieee.org/abstract/document/8588318>.
- Bello, C. A. (2 de septiembre de 2015). *Indicadores turísticos Cartagena de Indias 2014-2015*. Obtenido de www.colombiatrade.com.co.
- Berné, C., García, M., García, E., & Mugica, J. (2013). Identificación y análisis de los criterios de cambios del sistema de distribución turístico asociados al uso intensivo de las tecnologías de la información y de la comunicación. *Investigaciones Europeas de Dirección y Economía de la Empresa*, 19, Issue 2, May-August, 90-101.

- Cámara de Comercio de Cartagena. (2017). *Cartagena en cifras*. Disponible en https://www.cccartagena.org.co/sites/default/files/publicaciones/cartagena_en_cifras-abril_2017_0.pdf
- Castro, J. M. C., & Martini, H. A. (2014). Potencia estadística y cálculo del tamaño del efecto en G* Power: complementos a las pruebas de significación estadística y su aplicación en psicología. *Salud & sociedad*, 5(2), 210-244.
- Consejo Mundial de Viajes y Turismo - WTTC. (2018). Disponible en <https://sp.wttc.org/> (consulta 18/10/2018).
- Cotelco. (2018). *Cartagena de Indias*. Obtenido de Cotelco Cartagena. Disponible en <http://www.hotelesencartagena.travel/cartagena-de-indias>.
- Da Silva, L. E. B., Elnabarawy, I., & Wunsch II, D. C. (2019). Dual vigilance fuzzy adaptive resonance theory. *Neural Networks*, 109, 1-5.
- Decreto 463 de 2016 (2016). Obtenido del Ministerio de Industria, Turismo y Comercio: http://www.mincit.gov.co/loader.php?lServicio=Documentos&lFuncion=-verPdf&id=79513&name=DECRETO_463_DE_2016.pdf&prefijo=file.
- Demsar, J., Curk, T., Erjavec, A., Gorup, C., Hocevar, T., Milutinovic, M., Mozina, M., Polajnar, M., Toplak, M., Staric, A., Stajdohar, M., Umek, L., Zagar, L., Zbon-tar, J., Zitnik, M., & Zupan, B. (2013). Orange: Data mining toolbox in Python. *Journal of Machine Learning Research*, 14(Aug), 2349-2353.
- Departamento Administrativo Nacional de Estadística (DANE). (2017). Muestra Mensual de Hoteles, Boletín Técnico, Septiembre. Disponible en http://www.dane.gov.co/files/investigaciones/boletines/mmh/cp_mmh_sep17.pdf.
- Dzemyda, G., Kurasova, O., Medvedev, V., & Dzemydaitė, G. (2019). Visualization of data: Methods, software, and applications. In *Advances in mathematical methods and high performance computing* (pp. 295-307). Cham: Springer.
- Giglio, S., Bertacchini, F., Bilotta, E., & Pantano, P. (2019). Using social media to identify tourism attractiveness in six Italian cities. *Tourism Management*, 72, 306-312.
- González, M. C. (2017). *Auge hotelero seguirá en 2018: están en fila*. Obtenido de Portafolio: <http://www.portafolio.co/economia/los-proyectos-hoteleros-que-llegaran-a-colombia-en-2018-504715>.

- Hassan, A. K. A., & Abdulwahhab, A. B. A. (2019). Location aspect based sentiment analyzer for hotel recommender system. *Iraqi Journal of Science*, 60(1), 143-156.
- Kannan, R., & Vasanthi, V. (2019). Machine learning algorithms with ROC curve for predicting and diagnosing the heart disease. In *Soft Computing and Medical Bioinformatics* (pp. 63-72). Singapore: Springer.
- Keshavarz, Y., & Jamshidi, D. (2018). Service quality evaluation and the mediating role of perceived value and customer satisfaction in customer loyalty. *International Journal of Tourism Cities*, 4(2), 220-244.
- Ku, C. H., Chang, Y. C., Wang, Y., Chen, C. H., & Hsiao, S. H. (2019, January). Artificial intelligence and visual analytics: A deep-learning approach to analyze hotel reviews & responses. In *Proceedings of the 52nd Hawaii International Conference on System Sciences* (pp. 5268-5277). Disponible en <https://scholarspace.manoa.hawaii.edu/bitstream/10125/59963/0523.pdf>.
- Kühnle, S., Martínez-Noël, G., Leclerc, F., Hayes, S. D., Harper, J. W., & Howley, P. M. (2018). Angelman syndrome-associated point mutations in the Zn²⁺-binding N-terminal (AZUL) domain of UBE3A ubiquitin ligase inhibit binding to the proteasome. *Journal of Biological Chemistry*, 293(47), 18387-18399.
- Lee, W. H., & Cheng, C. C. (2018). Less is more: A new insight for measuring service quality of green hotels. *International Journal of Hospitality Management*, 68, 32-40.
- Lestari, Y. D., & Laode, M. I. (2018). Service innovation of 3/2 star hotel in Bandung. *The Journal of Asian Finance, Economics and Business (JAFEB)*, 5(3), 73-80.
- Lestari, Y. D., & Saputra, D. (2018). Market study on hospitality sector: Evidence from 4/5 star hotel in Bandung city Indonesia. *International Journal of Business & Society*, 19(1), 1-14.
- Lis-Gutiérrez, J.-P., Aguilera-Hernández, D., Escobedo-David, R. (2018). Demandas de los integrantes del ejército en calidad de víctimas (1997-2017): una aplicación de *machine learning* [mimeo].
- Lis-Gutiérrez, J.P., Moros Ochoa, A., Russi, M.T., Vargas-García, C.A., Lis-Gutiérrez, M. y Castro, Y. (2019). Recomendación de hoteles en Montevideo: una predicción mediante inteligencia artificial (168-190). En C. Henao, J.P. Lis-Gutiérrez y M. Gaitán. *Técnicas de análisis cuantitativo aplicado*. Bogotá: Uniminuto.

- Ministerio de Industria, Turismo y Comercio. (2017). *12 corredores turísticos serán el motor de las regiones*. Disponible en http://www.mincit.gov.co/publicaciones/37730/12_corredores_turisticos_seran_el_motor_de_las_regiones.
- Monsalve-Castro, C., & Hernández-Rueda, S. I. (2015). Gestión de la calidad del servicio en la hotelería como elemento clave en el desarrollo de destinos turísticos sostenibles: caso Bucaramanga. *Revista EAN*, (78), 160-173.
- Moreno, M. C. M., & Moreno, M. D. C. M. (2016). Satisfacción del usuario y calidad del servicio en alojamientos turísticos del estado Mérida, Venezuela. *Revista de Ciencias Sociales (Ve)*, 22(2), 111-131.
- Moros O, Maria A, Castro N, Gilmer Y, Viloría, Amelec, & Rincon V, Juan C. (2016b). Caltic to measure quality of service in Bogotá Hotels. *International Journal of Control Theory and Applications (IJCTA)*, 9(44),183-188.
- Moros O, Maria A; Rincón V, Juan C; Castro N Gilmer Y; Viloría, Amelec & Ariza S, Janitza. (2016a). Adaptation of the “CALTIC” Service Quality Model in the Tourism Sector. *International Journal of Control Theory and Applications (IJCTA)*, 9(44), 161-165.
- Nilashi, M., Ahani, A., Esfahani, M. D., Yadegaridehkordi, E., Samad, S., Ibrahim, O., ..., & Akbari, E. (2019). Preference learning for eco-friendly hotels recommendation: A multi-criteria collaborative filtering approach. *Journal of Cleaner Production*, 215, 767-783.
- Parasuraman, A., Berry, L., & Zeithaml, V. (1988). Servqual: A multiple-item scale for measuring consumer perceptions of service quality. *Journal of Retailing*, 64, 2-40. And reassessment of the Servqual scale. *Journal of Retailing*, 67 (winter), 420-450.
- Parasuraman, A., Berry, L., & Zeithaml, V. (1994). Reassessment o expectations as a comparison standar in measuring service quality: Implications for futher research. *Journal of Marketing*, 58 (January).
- Sasser, W., Olsen, R., & Wyckoff, D. (1978). *Management of service operations: Text and cases*. Boston, Mass: Allyn and Bacon.

- Shin, S., Du, Q., & Xiang, Z. (2019). What's vs. how's in online hotel reviews: Comparing information value of content and writing style with machine learning. In *Information and communication technologies in tourism 2019* (pp. 321-332). Cham: Springer.
- Sun, S., Wei, Y., Tsui, K. L., & Wang, S. (2019). Forecasting tourist arrivals with machine learning and internet search index. *Tourism Management*, 70, 1-10.
- Sunil, M. E., & Vinay, S. (2019). Sentimental analysis tools. In *Extracting knowledge from opinion mining* (pp. 204-231). IGI Global.
- UNWTO (2018). Panorama OMT del turismo internacional. Edición 2018. Madrid: UNWTO. Disponible en <https://www.e-unwto.org/doi/pdf/10.18111/9789284419890>
- Vega, A. V. R., Casielles, R. V., & Martín, A. M. D. (2015). La calidad percibida del servicio en establecimientos hoteleros de turismo rural. *Papers de Turisme*, (19), 17-33.
- Vergara, J. C., Quesada, V. M., & Blanco, I. (2011). Análisis de la calidad en el servicio y satisfacción de los usuarios en dos hoteles cinco estrellas de la ciudad de Cartagena (Colombia) mediante un modelo de ecuaciones estructurales. *Ingeniare. Revista Chilena de Ingeniería*, 19(3), 420-428.
- Wu, C. C., Yeh, W. C., Hsu, W. D., Islam, M. M., Nguyen, P. A. A., Poly, T. N., ..., & Li, Y. C. J. (2019). Prediction of fatty liver disease using machine learning algorithms. *Computer Methods and Programs in Biomedicine*, 170, 23-29.